

Trabajo Fin de Grado

Predicción de la luxación de la cadera mediante una
herramienta computacional basada en redes
neuronales

Prediction of hip dislocation by a computational
tool based on neural networks

Autor

Juan José Martínez Zapata

Director

Mónica Remacha Andrés

Escuela Universitaria Politécnica La Almunia
2016



**ESCUELA UNIVERSITARIA POLITÉCNICA
DE LA ALMUNIA DE DOÑA GODINA (ZARAGOZA)**

MEMORIA

Predicción de la luxación de la cadera
mediante una herramienta computacional
basada en redes neuronales

Prediction of hip dislocation by a
computational tool based on neural networks

424.16.101

Autor: Juan José Martínez Zapata

Director: Mónica Remacha Andrés

Fecha: Julio 2016

INDICE DE CONTENIDO

1. RESUMEN	1
2. ABSTRACT	2
3. INTRODUCCIÓN	3
3.1. LA BIOMECÁNICA	3
3.2. ARTROPLASTIA TOTAL DE CADERA Y SU LUXACIÓN	3
3.3. OBJETIVOS	4
4. DESCRIPCIÓN DEL TRABAJO	5
5. ARTROPLASTIA TOTAL DE CADERA Y SU LUXACIÓN	6
5.1. LA ARTICULACIÓN DE LA CADERA Y SU BIOMECÁNICA	6
5.1.1. <i>Región pélvica</i>	6
5.1.2. <i>Huesos de la cintura pélvica</i>	6
5.1.3. <i>Estructura del fémur</i>	7
5.1.4. <i>Articulación de la cadera</i>	8
5.1.5. <i>Músculos de la pelvis</i>	8
5.1.6. <i>Nervios de la región pélvica</i>	9
5.1.7. <i>Irrigación de la región pélvica</i>	10
5.1.8. <i>Biomecánica de la cadera</i>	11
5.2. ARTROPLASTIA TOTAL DE CADERA	12
5.3. LUXACIÓN DE LA CADERA PROTÉSICA	14
5.4. CLASIFICACIÓN DE LA LUXACIÓN PROTÉSICA	15
6. RED NEURONAL ARTIFICIAL	17
6.1. MODELO NEURONAL BIOLÓGICO	17
6.2. MODELO NEURONAL ARTIFICIAL	19
6.2.1. <i>Neurona artificial</i>	19
6.2.1.1. Entradas y salidas	21
6.2.1.2. Pesos sinápticos	21
6.2.1.3. Regla de propagación	21
6.2.1.4. Función de activación	21
6.2.1.5. Función de salida	22
6.2.2. <i>Arquitectura de una red neuronal</i>	23

INDICES

6.2.2.1.	Funcionamiento de la red neuronal	23
6.2.2.1.1.	Fase de entrenamiento	24
6.2.2.1.2.	Fase de operación o test	24
6.2.3.	<i>Redes neuronales con conexión hacia delante</i>	25
6.2.3.1.	Perceptrón simple	25
6.2.3.2.	Perceptrón multicapa (MLP)	25
6.2.4.	<i>Entrenamiento de la red neuronal</i>	26
6.2.4.1.	Algoritmo Backpropagation	27
6.2.4.2.	Generalización	27
7.	MATERIAL Y MÉTODOS	29
7.1.	DESARROLLO DEL MODELO POR ELEMENTOS FINITOS	29
7.1.1.	<i>Geometría y modelo de elementos finitos</i>	29
7.1.2.	<i>Propiedades del material y no linealidad del problema simulado</i>	32
7.1.3.	<i>Condiciones de contorno y movimientos simulados</i>	32
7.2.	DESARROLLO DE LA HERRAMIENTA MEDIANTE REDES NEURONALES	34
7.2.1.	<i>Entradas de la herramienta</i>	34
7.2.2.	<i>Salidas de la herramienta</i>	36
7.2.3.	<i>Entrenamiento de la herramienta</i>	38
7.2.4.	<i>Evaluación de los entrenamientos</i>	39
8.	RESULTADOS	41
8.1.	RESULTADOS DEL MODELO POR ELEMENTOS FINITOS	41
8.1.1.	<i>Posición del acetábulo y diámetro de la cabeza protésica</i>	41
8.2.	VALIDACIÓN DE LA HERRAMIENTA PRECLÍNICA DE PREDICCIÓN DE LUXACIÓN DE CADERA	45
8.3.	RESULTADOS DE LA HERRAMIENTA PRECLÍNICA	48
9.	CONCLUSIONES Y LÍNEAS FUTURAS	50
9.1.	CONCLUSIONES	50
9.2.	FUTURAS LÍNEAS DE INVESTIGACIÓN	53
10.	BIBLIOGRAFÍA	54

INDICE DE FIGURAS

Figura 3. 1 A-Posición correcta de los componentes en la artroplastia primaria. B- Luxación protésica.(«Casos clinicos de residentes SECOT - Visor», s. f.).	4
Figura 4. 1 Movimientos de la prótesis de cadera.	5
Figura 5. 1 Anatomía de la cadera. («CIENCIAS BIOLOGICAS», s. f.).	6
Figura 5. 2 Anatomía del fémur. («BIOLOGIA SISTEMA APARATO», 2011).	7
Figura 5. 3 Articulación de la cadera. («Recomendaciones para pacientes con prótesis total de cadera», s. f.).	8
Figura 5. 4 Músculo de la pelvis. («Músculo pectíneo», 2015).	9
Figura 5. 5 Nervios de la región pélvica. (SAS, s. f.).	10
Figura 5. 6 Irrigación de la región pélvica.	11
Figura 5. 7 Prótesis de cadera («Guía básica tras PTC por vía posterior (en construcción)», 2012).	12
Figura 5. 8 Prótesis de cadera porosa. («Prótesis acetabular clásica / no cementada - Plasmacup® Acetabular Cup», s. f.).	13
Figura 5. 9 Cadera afectada por artrosis (Saluspot, s. f.).	14
Figura 5. 10 Luxación posterior (Martín Gracia, 2009).	16
Figura 5. 11 Luxación anterior (Martín Gracia, 2009).	16
Figura 6. 1 Neurona biológica. («Redes Neuronales», s. f.).	17
Figura 6. 2 Conjunto de neuronas biológicas (Salud, 2015).	18
Figura 6. 3 Neurotransmisores. («Annabell, la red de neuronas artificiales», 2016).	19
Figura 6. 4 Esquema básico de un modelo neuronal artificial. (Trujillano Cabello et al., 2005).	20
Figura 6. 5 Esquema de una neurona artificial.(«INTELIGENCIA ARTIFICIAL», s. f.).	20
Figura 6. 6 Perceptrón multicapa (MLP).	26
Figura 6. 7 Generalización: (a) Situación idealizada; (b) Situación real.	28

INDICES

Figura 7. 1 Diámetro del acetábulo.	29
Figura 7. 2 Croquis y diseño 3D del acetábulo.	29
Figura 7. 3 Croquis y diseño 3D de la cabeza.	30
Figura 7. 4 Croquis y diseño 3D del vástago.	30
Figura 7. 5 Modelo 3D de la prótesis.	30
Figura 7. 6 Modelo mallado en EF.	31
Figura 7. 7 Modelo 3D de la prótesis con sus ejes de coordenadas.	32
Figura 7. 8 Movimientos de la prótesis.	32
Figura 7. 9 Modelo 3D combinación de ángulos (Anteversión y Abducción).	33
Figura 7. 10 Modelo 3D de las rotaciones simuladas (a) Extensión (b) Flexión en el momento de producirse el impingement.	33
Figura 7. 11 Esquema de la herramienta preclínica.	34
Figura 7. 12 (a) Coxometría de parámetros anatómicos y (b) Proyección anteroposterior.	35
Figura 7. 13 Proyección de Dunlap con cadera en flexión de 90° y muslo en abducción de 10°.....	35
Figura 7. 14 Obtención del ángulo de anteversión (a) aparente y (b) verdadero.	36
Figura 7. 15 Estructura interna Red neuronal.	37
Figura 7. 16 Entrenamiento de la red con Matlab.	39
Figura 7. 17 Esquema de validación cruzada.	40
Figura 8. 1 Estudio de Abaqus del Impingement y la Luxación.	41
Figura 8. 2 Resultados Diámetro 22mm.	42
Figura 8. 3 Resultados Diámetro 28mm.	42
Figura 8. 4 Resultados Diámetro 32mm.	43
Figura 8. 5 Resultados Diámetro 36mm.	43
Figura 8. 6 Resultados Diámetro 40mm.	44
Figura 8. 7 Resultados Diámetro 44mm.	44

Figura 8. 8 Elección de la red más adecuada.	46
Figura 8. 9 Comparativas de resultados del método de EF con el método de Redes Neuronales: a) red IMP-EE y b) red IMP-FI.	47
Figura 8. 10 Comparativas de resultados del método de EF con el método de Redes Neuronales: a) red LUX-EE y b) red LUX-FI.	47
Figura 8. 11 Rango de resultados de la Herramienta Preclínica.	48
Figura 8. 12 (a) Paciente en flexión y (b) Paciente en extensión («Guía para el paciente con Prótesis Total de Cadera», s. f.).....	49
Figura 9. 1 Zona de seguridad.....	50
Figura 9. 2 Proceso del estudio de la luxación de cadera específico para un paciente.	51
Figura 9. 3 Porcentaje de riesgo a) Impingement Extensión-Externa; b) Impingement Flexión-Interna; c) Luxación Extensión-Externa y d) Luxación Flexión-Interna.....	52
Figura 9. 4 Porcentaje de riesgo de luxación de cadera por paciente.	52

INDICE DE TABLAS

Tabla 6. 1 Funciones de activación utilizadas en los distintos modelos de redes neuronales artificiales.....	22
Tabla 7. 1 Elementos y modos del modelo.	31
Tabla 8. 1 Resultados de la herramienta preclínica.	49

1. RESUMEN

La luxación de prótesis de cadera es una de las complicaciones más frecuentes tras una artroplastia total de cadera produciéndose aproximadamente en un 10% de ellas. Existen gran cantidad de factores de riesgo por los que se puede producir una luxación de cadera, entre los más importantes se encuentran el tamaño de la cabeza protésica, la posición del acetábulo y el rango de movimiento. El objetivo de este Trabajo Fin de Grado (TFG) es el desarrollo de una herramienta preclínica capaz de predecir el riesgo de luxación de prótesis de cadera a partir de un modelo paramétrico de elementos finitos (EF) y Redes Neuronales Artificiales (RNA).

Para poder alcanzar este objetivo se han planteado una serie de apartados. En primer lugar, se desarrolla un modelo de elementos finitos (EF) paramétrico de una prótesis de cadera. Se han parametrizado tres factores clave en una luxación de cadera: diámetro de la cabeza (22, 28, 32, 36, 40 y 44 mm de diámetro), ángulo de anteversión (0° , 5° , 10° , 20° , 30° y 40°) y un ángulo de abducción (inclinación) del acetábulo (20° , 30° , 40° , 50° , 60° y 70°). Se ha realizado un análisis del efecto que produciría cada parámetro sobre la luxación y sobre lo que llamaremos como "impingement", que es el momento en el que empieza el pinzamiento del acetábulo. El impingement se produce antes que la luxación. Para este análisis se han simulado los movimientos de rotación interna y externa en dos posiciones de la extremidad; extensión y flexión.

Los resultados obtenidos en el estudio por elementos finitos (EF) se han utilizado para desarrollar cuatro Redes Neuronales Artificiales (RNA) independientes que componen distintos casos que se producen en una prótesis de cadera (Impingement en Extensión-Externa, Impingement en Flexión-Interna, Luxación en Extensión-Externa y Luxación en Flexión Interna).

Con esas Redes Neuronales Artificiales se ha podido hacer una herramienta preclínica para que el médico y los propios pacientes mediante una radiografía de la prótesis puedan coger los parámetros necesarios y así saber si tienen un riesgo alto, medio o bajo de tener una luxación de cadera.

2. ABSTRACT

Dislocation is a serious complication of total hip arthroplasty (THA), which is caused in, approximately, a 10 % of THA. There is a large amount of risk factors through which dislocation can take place. Among the most important ones, we can find the following: the size of the femoral head, position of the acetabulum and the range of movement. The goal of this Final Project is the development of a preclinical tool that is able to predict the risk of dislocation, based on a 3D parametric finite element model (FE) and Artificial Neural Networks (ANN).

In order to reach this goal, first of all, a 3D parametric finite element model (FE) of a THA is created. Three key factors in dislocation stability have been parametrized: femoral head diameter (diameter of 22, 28, 32, 36, 40 and 44 mm), anteversion angle (0° , 5° , 10° , 20° , 30° and 40°) and an abduction angle (lean) of the acetabular cup (20° , 30° , 40° , 50° , 60° and 70°). An analysis of the effect that each parameter has on the dislocation and on what we will call "impingement" —the moment when the clamping of the acetabulum begins— has been made. The impingement takes place before the dislocation. To perform this analysis, two activities have been simulated; external extension and internal flexion.

The results obtained in the project through the finite elements (FE) have been used to develop four independent Artificial Neural Networks (ANN) which gather different situations that take place in THA: Impingement in External-Extension, Impingement in Internal-Flexion, Luxation in External-Extension and Luxation in Internal-Flexion.

With these Artificial Neural Networks, a preclinical tool has been created so that the clinician could estimate the dislocation stability risk (high, medium as low) that a patient could suffer depending on the femoral head size and acetabular cup position.

3. INTRODUCCIÓN

3.1. LA BIOMECÁNICA

La biomecánica es la disciplina que estudia los modelos, fenómenos y leyes que sean relevantes en el movimiento de los seres vivos. Es una disciplina científica que tiene por objeto el estudio de las estructuras de carácter mecánico que existen en los seres vivos, fundamentalmente del cuerpo humano. Esta área de conocimiento se apoya en diversas ciencias biomédicas, utilizando los conocimientos de la mecánica, la ingeniería, la anatomía, la fisiología y otras disciplinas, para estudiar el comportamiento del cuerpo humano y resolver los problemas derivados de las diversas condiciones a las que puede verse sometido («Biomecánica», 2016).

3.2. ARTROPLASTIA TOTAL DE CADERA Y SU LUXACIÓN

La cadera, como todas las articulaciones del cuerpo con el paso del tiempo, se pueden desgastar o envejecer con la pérdida del cartílago de su superficie (artrosis de cadera), o fracturar por un traumatismo o por tener unos huesos frágiles debido a la osteoporosis. Tanto la artrosis con las fracturas son los dos principales motivos por los que muchas personas, tienen que pasar por el quirófano para ponerse una prótesis de cadera que reemplace la articulación desgastada o dañada.

La luxación de la cadera cuando se ha colocado una prótesis es una de las complicaciones más frecuentes produciéndose en un 10% de ellas. La luxación se produce cuando la parte de la prótesis que está en el fémur se separa de la parte de la prótesis anclada en la pelvis. Existen numerosos factores de riesgo por los cuales se produce una luxación de cadera, entre los que se encuentran el tamaño de la cabeza de la prótesis, la posición del acetábulo y el rango de movimiento (Ameneiro-Romero et al., 2005).




Figura 3. 1 A-Posición correcta de los componentes en la artroplastia primaria. B-Luxación protésica. («Casos clínicos de residentes SECOT - Visor», s. f.).

3.3. OBJETIVOS

El objetivo de este TFG es desarrollar una herramienta que pueda ser usada por el clínico para evitar la luxación. Para conseguir este objetivo se han definido unos objetivos secundarios que se indican a continuación:

- Simular el movimiento de luxación de la cadera en función de distintos parámetros:
 - Tamaño de la cabeza protésica.
 - Ángulo de inclinación del acetábulo.
 - Ángulo de anteversión del acetábulo.
 - Rango de movimiento.
- Establecimiento de una zona segura que pueda ayudar a reducir el número de luxaciones.
- Diseño de una base de datos para la predicción de la luxación de la cadera basada en redes neuronales artificiales.

4. DESCRIPCIÓN DEL TRABAJO

La realización de este TFG va a tener dos partes bien diferenciadas:

- La primera es el modelado mediante elementos finitos de una prótesis de cadera en 3D con el software Abaqus CAE v6.14 para la realización de un modelo paramétrico que simule la luxación teniendo en cuenta diferentes parámetros:
 - Diámetro de la cabeza.
 - Ángulo de abducción (α).
 - Ángulo de anteversión (β).

Se estudiarán dos movimientos de la articulación que son unos de los principales generadores de la luxación:

- Sentado cuando se cruza la pierna (flexión interna)
- De pie cuando se gira la pierna hacia afuera (extensión externa)




Figura 4. 1 Movimientos de la prótesis de cadera.

- La segunda parte de TFG va a ser la realización del código con Matlab de una red neuronal, para ello, se le introducirán los datos obtenidos anteriormente, teniendo en cuenta, el número de muestras a entrenar y a testear, con el fin de comprobar que funciona correctamente la red.

5. ARTROPLASTIA TOTAL DE CADERA Y SU LUXACIÓN

5.1. LA ARTICULACIÓN DE LA CADERA Y SU BIOMECÁNICA

5.1.1. Región pélvica

La región pélvica es la parte del tronco que se encuentra en la región posterior e inferior al abdomen y se considera el lugar de transición del tronco y las extremidades. Está compuesta de huesos, ligamentos y músculos. Los huesos que componen la región pélvica se conocen como cintura pélvica, pelviana o cadera (Moore & Dalley, 2009).

5.1.2. Huesos de la cintura pélvica

La cintura pélvica consta de dos huesos coxales que se unen por delante a través de la sínfisis del pubis y por detrás mediante la articulación sacroilíaca. El anillo completo que se forma provee un soporte sólido y estable a la columna vertebral y a los órganos de la pelvis, tales como la vejiga urinaria, las porciones terminales de los uréteres, los órganos genitales y el recto (Tortora, Derrickson, & Dvorkin, 2006).




Figura 5. 1 Anatomía de la cadera. («CIENCIAS BIOLÓGICAS», s. f.).

Cada uno de los huesos coxales está formado por tres huesos separados por cartílagos llamados ilion, isquion y pubis. El ilion se encuentra en la región superior, el pubis en la región inferior y anterior, finalmente el isquion está en la región inferior y posterior. La Figura 5.1 muestra un diagrama con estos huesos.

5.1.3. Estructura del fémur

El fémur, el hueso del muslo, es el hueso más largo, más pesado y más resistente de todos los huesos del cuerpo. Su extremo proximal se articula con el acetábulo y su extremo distal se articula con la tibia y la rótula o patela. El cuerpo o diáfisis del fémur se encuentra inclinado en dirección medial y esta característica es más prominente en las mujeres dado que tienen la región pélvica más ancha.

La Figura 5.2 muestra las principales partes del fémur. En el extremo proximal está la cabeza, el cuello, el trocánter mayor y menor. Estos dos son proyecciones surgidas de la zona de unión del cuello con el cuerpo y actúan como sitio de inserción para diferentes tendones de los músculos del muslo y de la región glútea, en medio de ellos se encuentra la línea intertrocantérica, que es importante de mencionar pues es un sitio común donde se observan fracturas de cadera. El trocánter mayor puede palparse y verse por delante de la depresión en los costados de la cadera.

En el extremo inferior del fémur se ubican el cóndilo medial y el cóndilo lateral, los cuales articulan con la tibia y es el lugar donde se insertan los ligamentos de la rodilla (Tortora et al., 2006).




Figura 5. 2 Anatomía del fémur. («BIOLOGIA SISTEMA APARATO», 2011).

5.1.4. Articulación de la cadera

La articulación de la cadera, llamada también articulación coxofemoral, está formada por la cabeza del fémur y el acetábulo del huso coxal. Está formada por una cápsula articular muy densa y fuerte, además de un grupo de ligamentos que permiten movimientos de flexión, extensión, aducción, circunducción y rotación medial y lateral del muslo. Algunos de estos componentes se ilustran en la Figura 5.3 (Tortora et al., 2006).




Figura 5. 3 Articulación de la cadera. («Recomendaciones para pacientes con prótesis total de cadera», s. f.).

5.1.5. Músculos de la pelvis

La mayoría de los músculos que mueven el fémur se originan en la cintura pelviana y se insertan en el fémur (Figura 5.4). A nivel de la articulación coxofemoral se encuentran los siguientes músculos y sus respectivas funciones, (Tortora et al., 2006):

- El iliopsoas flexiona el muslo e interviene en la rotación lateral y flexión del tronco.
- El ilíaco y el músculo glúteo mayor extienden y rotan en dirección medial.
- El glúteo medio y menor abducen el muslo y rotan en dirección medial.
- El tensor de la fascia lata está localizado en la superficie lateral y su función es flexionar y abducir el muslo.
- El piriforme, obturador interno y externo, gemelo superior e inferior y el cuadrado femoral rotan lateralmente el muslo.
- El aductor largo, corto y mayor aducen, flexionan y rotan medialmente el muslo
- El pectíneo flexiona y aduce el muslo.




Figura 5. 4 Músculo de la pelvis. («Músculo pectíneo», 2015).

5.1.6. Nervios de la región pélvica

El plexo sacro es un conjunto de axones que nacen de las raíces anteriores de los nervios espinales L4-L5 y S1-S4. Se disponen a lo largo de la cara anterior del hueso sacro e inervan glúteos, el periné y los miembros inferiores. El nervio ciático, considerado el más largo del cuerpo, tiene su origen en este plexo (Tortora et al., 2006).

Algunos de los nervios más importantes de este plexo y su respectiva distribución se muestran en la Figura 5.5 Y se mencionan a continuación:

- El glúteo superior inerva los músculos glúteo menor, mediano y tensor de la fascia lata.
- El glúteo inferior, piriforme, cuadrado femoral, gemelo inferior y el obturador interno inervan los músculos que llevan el mismo nombre.
- El obturador interno inerva los músculos obturador interno y gemelo superior.
- El ciático, formado por el tibial común y el peroneo común que inervan varios músculos de la pierna.
- El pudendo que inerva los músculos del periné, piel del pene y del escroto del hombre, del clítoris, labios mayores, labios menores y la vagina en la mujer.

- El plexo coccígeo es una pequeña red de fibras nerviosas formadas por los ramos anteriores de S4 y S5 y por los nervios coccígeos y a pesar de que nace en la región pélvica, no tiene relación directa con músculos de la cadera.




Figura 5. 5 Nervios de la región pélvica. (SAS, s. f.).

5.1.7. Irrigación de la región pélvica

Las arterias que entran en la pelvis provienen de la arteria iliaca común que a su vez es una rama de la aorta descendente (Figura 5.6). Entre las principales se encuentran, (Tortora et al., 2006):

- Las arterias iliacas internas, consideradas las arterias de la pelvis, emiten ramas a las nalgas. Región medial del muslo y el perineo.
- La arteria sacra media, que irriga las últimas vértebras lumbares, sacro y cóccix.
- La arteria rectal superior, que irriga la porción superior del recto y se une con las arterias rectales media e inferior, quienes son ramas de la iliaca interna.

La arteria iliaca externa se prolonga hacia el muslo y se convierte en la arteria femoral. Aunque no es considerada una arteria de la cadera, es importante de mencionar pues su recorrido se encuentra relativamente cerca de la articulación coxofemoral.

La sangre que proviene de las vísceras pélvicas retorna al corazón vía la vena cava inferior. La principal de ellas es la vena iliaca interna, que drena no solo los órganos de internos de la pelvis sino también el muslo, los glúteos y los genitales externos.




Figura 5. 6 Irrigación de la región pélvica.

5.1.8. Biomecánica de la cadera

La articulación coxofemoral es una enartrosis de coaptación muy firme. Posee una menor amplitud de movimientos en relación con la articulación escapulohumeral, pero posee una estabilidad mayor (Popowski et al., 1991).

Ejes de movimiento

- Eje transversal: situado en un plano frontal, se realizan dos movimientos de FLEXIÓN-EXTENSIÓN.
- Eje anteroposterior: situado en un plano sagital, se efectúan los movimientos de ABDUCCIÓN-ADUCCIÓN.
- Eje vertical: permite los movimientos de ROTACIÓN EXTERNA-ROTACIÓN INTERNA.

5.2. ARTROPLASTIA TOTAL DE CADERA

La artroplastia de cadera consiste en una cirugía ortopédica que busca reemplazar de forma total o parcial la articulación de la cadera con un implante artificial llamado prótesis. El objetivo es reemplazar las partes de la articulación que han sido dañadas y aliviar el dolor, cuando no se puede controlar con otros tratamientos o estos han fallado.

La prótesis total de cadera consta de tres partes (Figura 5.7):

- Una copa que reemplaza el acetábulo de la cadera.
- Una esfera metálica o de cerámica que reemplaza la cabeza femoral fracturada.
- Un vástago metálico que se adhiere al cuerpo del hueso para agregarle estabilidad a la prótesis.




Figura 5. 7 Prótesis de cadera («Guía básica tras PTC por vía posterior (en construcción)», 2012).

Hoy dos tipos de fijación principales: cementada y porosa. Las dos pueden ser eficaces en la sustitución de la articulación de la cadera. El cirujano escoge la solución que mejor se adapta a las necesidades del paciente.

- **Implante de cadera cementado**

El implante de cadera cementado está diseñado para su colocación con cemento óseo (una masa que contribuye a la colocación del implante en el interior del hueso). El cemento óseo se inyecta en el canal femoral preparado. A continuación, el cirujano coloca el implante en el interior del canal y la masa ayuda a fijarlo en la posición deseada.

- **Implante de cadera poroso**

El implante de cadera poroso se inserta en el canal femoral preparado sin necesidad de fijarlo con comente óseo (Figura 5.8). En primer lugar, el canal femoral se prepara de modo que el implante encaje perfectamente en su interior. Las superficies porosas del implante de cadera están diseñadas para atraer el hueso del interior del canal y permitir su integración en la superficie porosa. Finalmente, esta osteointegración puede proporcionar una fijación adicional para mantener el implante en la posición deseada.



Figura 5. 8 Prótesis de cadera porosa. («Prótesis acetabular clásica / no cementada - Plasmacup® Acetabular Cup», s. f.).

La artroplastia total de cadera puede estar indicada en:

- Artritis (reumatoide, enfermedad de Still, etc).
- Espondilitis anquilosante.
- Necrosis avascular.
- Artropatía degenerativa (artrosis).
- Fractura.
- Enfermedades hereditarias.
- Displasia evolutiva de cadera.

La artrosis es la causa más habitual en el reemplazo total de cadera, ésta afecta a personas de mediana y avanzada edad. Los síntomas van desde unas leves molestias hasta un dolor severo incapacitante. El tratamiento de la artrosis de cadera persigue la disminución del dolor y mejora de la movilidad de la articulación.

La artrosis puede producirse debido a una incongruencia mecánica de las superficies articulares, lo que inicia una cadena de fenómenos metabólicos que determinan la disgregación del cartílago (Pritzker, 2009).




Figura 5. 9 Cadera afectada por artrosis (Saluspot, s. f.).

5.3. LUXACIÓN DE LA CADERA PROTÉSICA

La artroplastia total de cadera (ATC) es un procedimiento muy frecuente en los Servicios de Cirugía Ortopédica y Traumatología, aunque su efectividad es muy elevada, no está exenta de complicaciones como son el aflojamiento aséptico, luxación, infección y fracturas periprotésicas.

A pesar de los avances en las técnicas y modelos protésicos, la luxación sigue siendo la segunda complicación más frecuente después del aflojamiento aséptico en las artroplastias totales de cadera. Se produce en el 0,3% al 10% de las artroplastias primarias de cadera y hasta en el 28% de las artroplastias de revisión (Blom et al., 2008).

El riesgo de luxación se ve influenciado por el abordaje quirúrgico, el diagnóstico que condiciona la artroplastia, el tiempo de evolución de la artroplastia y por la situación general del paciente, por lo que podemos decir que la etiología de la luxación protésica es multifactorial pudiendo dividirse las causas en las derivadas de las características del paciente, de la técnica quirúrgica empleada y del material empleado.

El mejor conocimiento de estos factores, así como el avance de las técnicas quirúrgicas ha permitido el descenso de la tasa de luxaciones en el tiempo (Padgett & Warashina, 2004).

Aunque la mayoría de las luxaciones tras una artroplastia primaria de cadera cursan como un episodio aislado y pueden ser tratadas con éxito de forma conservadora, algunos pacientes requieren tratamiento quirúrgico para evitar la recaída de la luxación (Daly & Morrey, 1992).

Las luxaciones precoces, ocurridas en los días siguientes a la intervención quirúrgica, no suelen recaer y son tratadas la mayor parte de las veces de forma satisfactoria mediante tratamientos conservador (von Knoch et al., 2002). Sin embargo, cuando se evidencia mal posicionamiento de los componentes, insuficiencia muscular sobre todos de los abductores u otros factores, es necesario recurrir al tratamiento quirúrgico para solucionar el problema. Las técnicas quirúrgicas a emplear se decidirán según la etiología del problema que es lo más complejo de determinar y resolver.

La inestabilidad en la prótesis de cadera está lejos de resolverse pues existen escasas líneas de investigación sobre este tema, cada vez más frecuente, por el aumento de la cirugía protésica, por la aparición de la modularidad protésica, por el aumento de los recambios y por el aumento de la longevidad de los pacientes y de la edad de las indicaciones, presentando en estas edades avanzadas una musculatura cada vez más atrófica.

No obstante, su número es progresivamente más frecuente por las causas enumeradas, pero porcentualmente continúa siendo afortunadamente una rara complicación de la artroplastia de cadera, por lo que sus estudios son escasos y de compleja realización llegándose rara vez a conclusiones definitivas por su origen multifactorial difícilmente identificable la mayor parte de las veces.

5.4. CLASIFICACIÓN DE LA LUXACIÓN PROTÉSICA

Las dos formas más importantes de hacer la clasificación de la luxación protésica de cadera:

1. Momento en el que se produce la luxación:

- **Luxación precoz:** durante las primeras 6-8 semanas tras la intervención quirúrgica. Son las más frecuentes. Coincide con el tiempo de reparación de las partes blandas circundantes a la artroplastia y la formación de una pseudocápsula que dotará de estabilidad a la artroplastia y evitará en cierto modo la luxación (Masaoka et al., 2006).
- **Luxación tardía:** fuera del periodo de luxación precoz. Se han descrito casos después de 10 años o más tras la cirugía (von Knoch et al., 2002).

2. Posición del componente femoral tras la luxación:

- **Luxación posterior:** aparece tras un movimiento de flexión, abducción y rotación interna. Esta es la posición adoptada al sentarse sobre sillas u objetos bajos, a escasos centímetros del suelo. Es el tipo más frecuente, con frecuencias del 75%-90%. (Meek et al., 2008).




Figura 5. 10 Luxación posterior (Martín Gracia, 2009).

- **Luxación anterior:** se produce tras un movimiento de extensión y rotación externa, sobre todo al asociarse con una vía de abordaje anterior y/o con una excesiva anteversión del componente acetabular.




Figura 5. 11 Luxación anterior (Martín Gracia, 2009).

6. RED NEURONAL ARTIFICIAL

Después del estudio de la luxación en el apartado anterior y los factores que le afectan para que se produzcan. Se utilizará toda esta información para buscar un modelo matemático que cuantifique el riesgo de luxación en función de los parámetros geométricos del paciente (\emptyset , α , β) además que sea automático.

Esto se va a conseguir mediante la aplicación de modelos matemáticos denominados, Redes Neuronales Artificiales (RNA). Estas suelen ser utilizadas con una herramienta para la predicción de tendencias basándose en un conjunto de algoritmos matemáticos que encuentran las relaciones no lineales entre conjuntos de datos. A continuación, se va a explicar la metodología desarrollada basada en RNA y su validación.

6.1. MODELO NEURONAL BIOLÓGICO

El cerebro es el elemento principal del sistema nervioso humano y está compuesto por un tipo especial de célula llamada neurona. Una neurona es una célula viva y como tal posee todos los elementos de las células biológicas. A su vez, las neuronas tienen características propias que le permiten comunicarse entre ellas, lo que las diferencia del resto de las células biológicas. En la Figura 6.1 Muestra la estructura típica de una neurona biológica.




Figura 6. 1 Neurona biológica. («Redes Neuronales», s. f.).

Como se observa la neurona biológica está compuesta por un cuerpo celular o soma, del cual se desprende un árbol de ramificaciones llamado árbol dendrítico, compuesto por las dendritas. Del soma también parte una fibra tubular, llamada, axón,

del cual suele ramificarse cerca de su extremo. Las dendritas actúan como un canal de entrada de señales provenientes desde el exterior hacia la neurona, mientras que el axón actúa como un canal de salida. El espacio entre dos neuronas vecinas se denomina sinapsis (Figura 6.2).

Desde un punto de vista funcional, las neuronas conforman un procesador de información sencillo. Constan de un subsistema de entrada (dendritas), un subsistema de procesamiento (soma) y un subsistema de salida (axón). Como característica principal destaca su capacidad de interacción con otras neuronas, las señales nerviosas pueden ser eléctricas o químicas. La transmisión química se da principalmente en la comunicación entre neuronas mientras que la eléctrica se produce dentro de una neurona (Martínez et al., 2013).




Figura 6. 2 Conjunto de neuronas biológicas (Salud, 2015).

En general, una neurona recibe información de cientos de neuronas vecinas y la transmite a otras tantas neuronas. La comunicación entre neuronas se lleva a cabo de la siguiente forma: el soma de las neuronas transmisoras genera un pulso eléctrico llamado potencial de acción. El pulso eléctrico se propaga a través del axón en dirección a las sinapsis. La información se transmite a las neuronas vecinas utilizando un proceso químico, mediante la liberación de neurotransmisores (Figura 6.3).

Esos neurotransmisores se transmiten a través de la sinapsis hacia la neurona receptora. La neurona receptora toma la señal enviada por cientos de neuronas a través de las dendritas y la transmite al cuerpo celular. Estas señales pueden ser excitadoras (positivas) o inhibitoras (negativas) (Gurney, 1997). El soma es el encargado de integrar la información proveniente de las distintas neuronas.



Figura 6. 3 Neurotransmisores. («Annabell, la red de neuronas artificiales», 2016).

Si la señal resultante supera un determinado umbral (umbral de disparo) el soma emite un pulso que se transmite a lo largo del axón dando lugar a la transmisión eléctrica a lo largo de la neurona. Al llegar la señal al extremo del axón se liberan neurotransmisores que permiten transmitir la señal a las neuronas vecinas (Nascimento et al., 2000).

6.2. MODELO NEURONAL ARTIFICIAL

6.2.1. Neurona artificial

La neurona artificial es un elemento de procesamiento simple que a partir de un vector de entradas produce múltiples salidas (Figura 6.4). En general podemos encontrar tres tipos de neuronas artificiales y podemos clasificarlas según su función en:

1. Neuronas de entrada (capa entrada): Son aquellas que reciben directamente la información desde el exterior.
2. Neuronas ocultas (capa oculta): Llamadas de esta forma a las neuronas que reciben la información desde otras neuronas artificiales. Es en estas neuronas donde se realiza la representación de la información almacenada.
3. Neuronas de salida (capa salida): Las cuales reciben la información ya procesada y la devuelven al exterior.

Red neuronal artificial

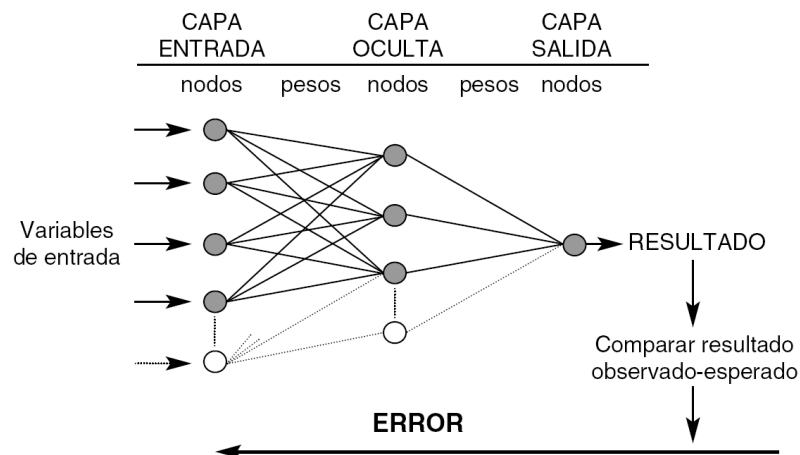


Figura 6. 4 Esquema básico de un modelo neuronal artificial. (Trujillano Cabello et al., 2005).

A su vez cada una de las neuronas está compuesta por los elementos de la Figura6.5:




Figura 6. 5 Esquema de una neurona artificial. («INTELIGENCIA ARTIFICIAL», s. f.).

- Conjunto de entradas, $\mathbf{x}_j(\mathbf{t})$: Reciben la información, esta puede ser proveniente del exterior o de otra neurona artificial.
- Pesos sinápticos, \mathbf{w}_{ij} : Representan el grado de comunicación entre dos neuronas artificiales. Estos pesos pueden ser excitadores o inhibidores.
- Regla de propagación, σ_i : Integra la información proveniente de las distintas neuronas artificiales, entradas y pesos sinápticos, y proporcionan el valor potencial postsináptico de la neurona.
- Función de activación, \mathbf{f}_i : Provee el estado de activación de la neurona i .
- Función de salida, \mathbf{F}_i : Representa la salida actual de la neurona i según la siguiente ecuación.

$$y_i(t) = F_i \left(f_i \left[a_i(t-1), \sigma_i \left(\omega_{ij}, x_j(t) \right) \right] \right) \quad (6.1)$$

6.2.1.1. Entradas y salidas

Las entradas y salidas de una neurona pueden ser clasificadas en dos grandes grupos, binarias o continuas. Las neuronas binarias (digitales) sólo admiten dos valores posibles. En general en este tipo de neurona se utilizan los siguientes dos alfabetos (0,1) o (-1,1). Por su parte, las neuronas continuas (analógicas) admiten valores dentro de un determinado rango, que en general suelen definirse como (-1,1). La selección del tipo de neurona a utilizar depende de la aplicación y del modelo a construir.

6.2.1.2. Pesos sinápticos

El peso sináptico w_{ij} define la fuerza de una conexión sináptica entre dos neuronas, la neurona presináptica i y la neurona postsináptica j . Los pesos sinápticos pueden tomar valores positivos, negativos o cero. En caso de una entrada positiva, un peso positivo actúa como excitador, mientras que un peso negativo actúa como inhibidor. En caso de que el peso sea cero, no existe comunicación entre el par de neuronas. Mediante el ajuste de los pesos sinápticos la red es capaz de adaptarse a cualquier entorno y realizar una determinada tarea.

6.2.1.3. Regla de propagación

La regla de propagación determina el potencial resultante de la interacción de la neurona i con las N neuronas vecinas. El potencial resultante h_i se puede expresar de la siguiente manera. La regla de propagación más simple y utilizada consiste en realizar una suma de las entradas ponderadas con sus pesos sinápticos correspondientes.

$$h_i(t) = \sigma_i(w_{ij}, X_j(t)) \quad (6.2)$$

$$h_i(t) = \sum w_{ij} \cdot X_j(t) \quad (6.3)$$

6.2.1.4. Función de activación

La función de activación determina el estado de activación actual de la neurona en base al potencial resultante h_i y al estado de activación anterior de la neurona $a_i(t-1)$. Existen distintos tipos de funciones de activación (Tabla 6.1). El estado de activación de la neurona para un determinado instante de tiempo t puede ser expresado de la siguiente manera:

$$a_i(t) = f_i(a_i(t-1), h_i(t)) \quad (6.4)$$

Sin embargo, en la mayoría de los modelos se suele ignorar el estado anterior de la neurona, definiéndose el estado de activación en función del potencial resultante h_i :

$$a_i(t) = f_i(h_i(t)) \quad (6.5)$$

Tabla 6. 1 Funciones de activación utilizadas en los distintos modelos de redes neuronales artificiales.

Función	Fórmula	Rango
Identidad	$Y = X$	$[-\infty, \infty]$
Escalón	$Y = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{si } x < 0 \end{cases}$	$[0, 1]$
	$Y = \begin{cases} 1 & \text{si } x > 0 \\ -1 & \text{si } x < 0 \end{cases}$	$[-1, 1]$
Lineal a tramos	$Y = \begin{cases} x & \text{si } -1 < x < 1 \\ 1 & \text{si } x > 1 \\ -1 & \text{si } x < -1 \end{cases}$	$[-1, 1]$
Sigmoidea	$Y = \frac{1}{1 + e^{-x}}$	$[0, 1]$
	$Y = \tanh(x)$	$[-1, 1]$
Sinusoidal	$Y = \text{sen}(\omega \cdot x + \psi)$	$[-1, 1]$

6.2.1.5. Función de salida

La función de salida proporciona el valor de la salida de la neurona, en base al estado de activación de la neurona. En general se utiliza la función identidad, es decir:

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad (6.6)$$

6.2.2. Arquitectura de una red neuronal

Una vez definida el tipo de neurona que se utilizará en un modelo de redes neuronales artificiales es necesario definir la topología de la misma. La organización y disposición de las neuronas dentro de una red neuronal se denomina topología, y viene dada por el número de capas, la cantidad de neuronas por capa, el grado de conectividad, y el tipo de conexión entre neuronas.

Las neuronas suelen agruparse en unidades funcionales denominadas capas. Se denomina capa de entrada a aquella que está compuesta por neuronas de entradas y por lo tanto recibe información procedente desde el exterior. Análogamente, se denomina capa oculta y capa de salida a aquellas capas que están compuestas por neuronas ocultas y de salida, respectivamente. Una red neuronal artificial está compuesta por una o más capas, las cuales se encuentran interconectadas entre sí. Entre un par de neuronas de la red neuronal artificial pueden existir conexiones. Estas conexiones son las sinapsis, tienen asociadas un peso sináptico, y son direccionales. Cuando la conexión se establece entre dos neuronas de una misma capa hablamos de conexiones laterales o conexiones intra-capa. Por el contrario, si la conexión se establece entre neuronas de distintas capas se la denomina conexión inter-capa. Si la conexión se produce en el sentido inverso al de entrada-salida la conexión se llama recurrente o realimentada.

Una red puede estar formada por una única capa de neuronas. En este caso hablamos de redes monocapa, y las neuronas que conforman dicha capa cumplen la función de neuronas de entrada y salida simultáneamente. Cuando la red está compuesta por dos o más capas hablamos de redes multicapa. A su vez, hablamos de redes neuronales con conexión hacia delante (redes feedforward) cuando las conexiones entre las distintas neuronas de la red siguen un único sentido, desde la entrada de la red hacia la salida de la misma. Cuando las conexiones pueden ser tanto hacia delante como hacia atrás hablamos de redes recurrentes (redes feedback).

6.2.2.1. Funcionamiento de la red neuronal

Durante el funcionamiento de una red neuronal podemos distinguir claramente dos fases o modos de operación: la fase de aprendizaje o entrenamiento, y la fase de operación o test. Durante la primera fase, la fase de aprendizaje, la red es entrenada para realizar un determinado tipo de procesamiento. Una vez alcanzado un nivel de entrenamiento adecuado, se pasa a la fase de operación, donde la red utilizada para llevar a cabo la tarea para cual fue entrenada.

6.2.2.1.1. Fase de entrenamiento

Una vez seleccionada el tipo de neurona artificial que se utilizará en una red neuronal y determinada su topología es necesario entrenarla para que la red pueda ser utilizada. Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. Durante el proceso de aprendizaje se va refinando iterativamente la solución hasta alcanzar un nivel de operación suficientemente bueno. El proceso de aprendizaje se puede dividir en tres grandes grupos de acuerdo a sus características en: (Isasi Viñuela & Galván León, 2004; Xin Yao, 1999)

- Aprendizaje supervisado: Se presenta a la red un conjunto de patrones de entrada junto con la salida esperada. Los pesos se van modificando de manera proporcional al error que se produce entre la salida real de la red y la salida esperada.
- Aprendizaje no supervisado: Se presenta a la red un conjunto de patrones de entrada. No hay información disponible sobre la salida esperada. El proceso de entrenamiento en este caso deberá ajustar sus pesos en base a la correlación existente entre los datos de entrada.
- Aprendizaje por refuerzo: Este tipo de aprendizaje se ubica entre medio de los dos anteriores. Se le presenta a la red un conjunto de patrones de entrada y se le indica a la red si la salida obtenida es o no correcta. Sin embargo, no se le proporciona el valor de la salida esperada. Este tipo de aprendizaje es muy útil en aquellos casos en que se desconoce cuál es la salida exacta que debe proporcionar la red.

6.2.2.1.2. Fase de operación o test

Una vez finalizada la fase de aprendizaje, la red puede ser utilizada para realizar la tarea para la que fue entrenada. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante la fase de entrenamiento.

6.2.3. Redes neuronales con conexión hacia delante

Este tipo de redes neuronales son las que mayor aplicación práctica tienen, se caracterizan por su organización en capas y conexiones estrictamente hacia delante, utilizando entrenamiento de tipo supervisado.

Dentro de este grupo destacaremos el perceptrón y el perceptrón multicapa (MLP) los cuales desarrollaremos a continuación.

6.2.3.1. Perceptrón simple

Este modelo tiene gran importancia histórica ya que fue el primer modelo en poseer un mecanismo de entrenamiento que permite determinar automáticamente los pesos sinápticos que clasifican correctamente a un conjunto de patrones a partir de un conjunto de ejemplos.

La arquitectura del perceptrón está compuesta por dos capas de neuronas, una de entrada y una de salida. La capa de entrada es la que recibe la información proveniente del exterior y la transmite a las neuronas sin realizar ningún tipo de operación sobre la señal de entrada. En general la información entrante es binaria. La función de activación de las neuronas de un perceptrón es del tipo escalón, dando de esta manera sólo salidas binarias. Cada neurona de salida del perceptrón representa a una clase. Una neurona de salida responde con 1 si el vector de entrada pertenece a la clase a la que representa y responde con 0 en caso contrario.

El algoritmo de entrenamiento del perceptrón se encuentra dentro de los denominados algoritmos por corrección de errores. Este tipo de algoritmos ajustan los pesos de manera proporcional a la diferencia entre la salida actual proporcionada por la red y la salida objetivo, con el fin de minimizar el error producido por la red.

6.2.3.2. Perceptrón multicapa (MLP)

El perceptrón multicapa es una extensión del perceptrón simple. La tipología de un perceptrón multicapa está definida por un conjunto de capas ocultas, una capa de entrada y una de salida. No existen restricciones sobre la función de activación, aunque en general se suelen utilizar funciones sigmoideas (Tabla 6.1). A continuación, se

expone en la Figura 6.6 el esquema tipo para una MLP, el cual es el modelo más utilizado actualmente y se ha utilizado en este TFG.

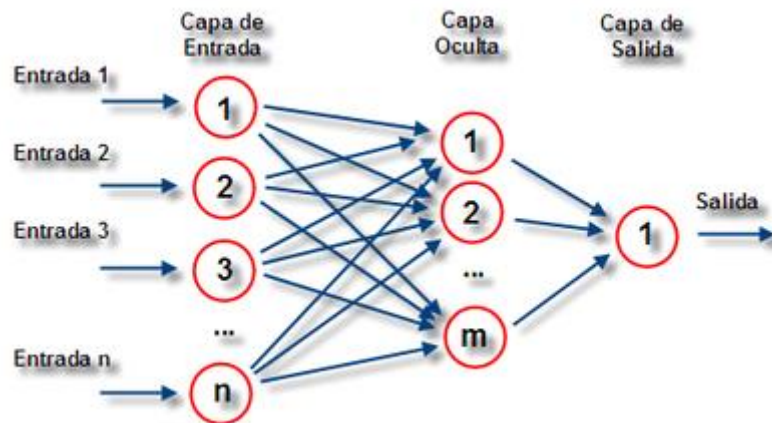


Figura 6. 6 Perceptrón multicapa (MLP).

6.2.4. Entrenamiento de la red neuronal

En el contexto de las redes neuronales el entrenamiento o aprendizaje puede ser visto como el proceso de ajuste de los parámetros libres de la red (Yao, 1995). Partiendo de un conjunto de pesos sinápticos aleatorios, el proceso de entrenamiento busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. Este proceso de entrenamiento, es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación lo suficientemente bueno.

La mayoría de los métodos de entrenamiento utilizados en las redes neuronales con conexión hacia delante consisten en proponer una función de error que mida el rendimiento actual de la red en función de los pesos sinápticos. El objetivo del método de entrenamiento es encontrar el conjunto de pesos sinápticos que minimizan (o maximizan) dicha función. El método de optimización proporciona una regla de actualización de los pesos que en función de los patrones de entrada modifica iterativamente los pesos hasta alcanzar el punto óptimo de la red neuronal.

6.2.4.1. *Algoritmo Backpropagation*

El algoritmo de entrenamiento/aprendizaje supervisado más común utilizado para una MLP, es el algoritmo llamado Backpropagation. Este algoritmo surgió de la búsqueda de un algoritmo para entrenar específicamente a la MLP. Es un tanto complejo ya que se toma la información del comportamiento de la red en el sentido directo de la red y en el sentido inverso, esto se realiza por la necesidad de modificar el comportamiento de las capas ocultas.

El algoritmo Backpropagation tiene como objetivo usar la diferencia entre las salidas deseadas y las salidas actuales en la capa de salida de la red para cambiar los pesos (indicados con valores aleatorios pequeños) con el fin de reducir al mínimo esta diferencia (error). Esto se logra mediante una serie de interacciones donde se modifica cada peso de derecha a izquierda (sentido inverso de la propagación de información en la red) hasta modificarse los pesos de la capa de entrada prosiguiendo nuevamente con la propagación de la información de entrada, esto hasta que la diferencia entre la salida deseada y la obtenida en cada neurona de salida sea mínima (Fritsch, 1996).

El algoritmo Backpropagation es el método que desde un principio se desarrolló con el fin de entrenar redes neuronales multicapa y se demostró su eficiencia en el entrenamiento de redes para resolver diversos problemas, pero en muchos casos resultó ser muy lento. A través de los años han surgido algoritmos más poderosos, aunque más complejos, la mayoría partiendo de la base de este algoritmo, por ejemplo, para propagar el error hacia atrás. De cualquier forma, es recomendable el uso de este algoritmo cuando se trata el diseño de una MLP, ya que no es demasiado complejo, se entiende fácilmente su finalidad, y sirve para comprender más rápido los algoritmos que se basan en él. Este es el método utilizado para el entrenamiento de este TFG.

6.2.4.2. *Generalización*

Una vez finalizada la fase de aprendizaje, la red puede ser utilizada para realizar la tarea para la que fue entrenada. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante la fase de entrenamiento (Chinrungrueng, 1988).

Cuando se evalúa una red neuronal no sólo es importante evaluar si la red ha sido capaz de aprender los patrones de entrenamiento. Es imprescindible también evaluar el comportamiento de la red ante patrones nunca antes vistos. Esta característica de las

Red neuronal artificial

redes neuronales se la conoce como capacidad de generalización y es adquirida durante la fase de entrenamiento. Es necesario que, durante el proceso de aprendizaje, la red extraiga las características de las muestras, para poder luego responder correctamente a nuevos patrones.

De lo dicho anteriormente surge la necesidad de evaluar durante la fase de entrenamiento dos tipos de errores. El **error de aprendizaje**, que indica la calidad de respuesta de la red a los patrones de entrenamiento y el **error de test**, que indica la calidad de la respuesta de la red a patrones nunca antes vistos.

Para poder obtener una medida de ambos errores es necesario dividir el set de datos disponibles en dos, el set de datos de entrenamiento, y el set de datos de test. El primero se utiliza durante la fase de entrenamiento para que la red pueda extraer las características de los mismos mediante el ajuste de sus pesos sinápticos, así la red logra una representación interna de la función. El set de test se utiliza para evaluar la capacidad de generalización de la red.

La causa más común de la pérdida de capacidad de generalización es el sobreaprendizaje. Esto sucede cuando la cantidad de ciclos de entrenamientos tiene a ser muy alta. Se observa que la respuesta de la red a los patrones de entrenamiento es muy buena mientras que la respuesta a nuevos patrones tiende a ser muy pobre. Al aumentar el número de ciclos la red tiende a sobreajustar la respuesta a los patrones de entrenamiento, a expensas de una menor capacidad de generalización. La Figura 6.7(a) muestra una situación idealizada de lo dicho anteriormente. En la misma se observa que un determinado punto se empieza a perder capacidad de generalización como consecuencia del sobreaprendizaje.




Figura 6. 7 Generalización: (a) Situación idealizada; (b) Situación real.

7. MATERIAL Y MÉTODOS

7.1. DESARROLLO DEL MODELO POR ELEMENTOS FINITOS

7.1.1. Geometría y modelo de elementos finitos

Para este trabajo se ha simulado un modelo protésico mediante el método de elementos finitos (EF) para hacer el estudio del efecto del diámetro de la cabeza de la prótesis, el ángulo de abducción (inclinación) y anteversión en el choque de los componentes y la posterior luxación de la prótesis.

Los tamaños de la cabeza considerados para hacer este estudio han sido 22, 28, 32, 36, 40 y 44 mm por ser los diámetros más usados y con mayor frecuencia en la práctica clínica. En todos los modelos se utilizó un diámetro exterior del acetábulo de 52 mm, como podemos ver en la siguiente imagen de un acetábulo real (Figura 7.1).



Figura 7. 1 Diámetro del acetábulo.

Para la realización del modelo paramétrico de EF se ha utilizado el software Abaqus CAE v6.14. Para ello la prótesis se compone de dos partes. Por una parte, el acetábulo de la prótesis que ha sido simulado como un sólido deformable mediante una revolución como podemos ver en la siguiente imagen (Figura 7.2).

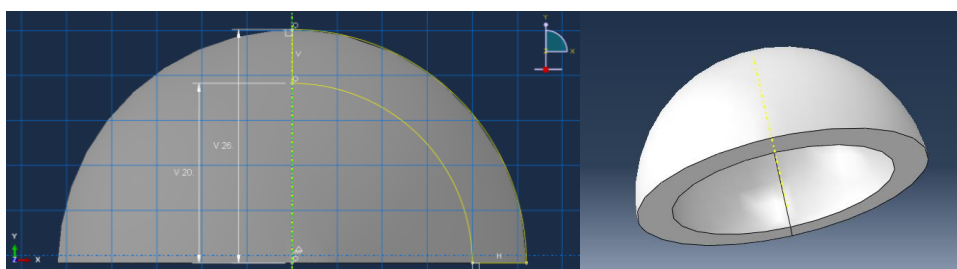


Figura 7. 2 Croquis y diseño 3D del acetábulo.

Material y métodos

La segunda parte del modelo consiste en dos partes, la cabeza y el vástago, los dos fueron simulados como una superficie rígida discreta. En el caso de la cabeza su diseño se realizó como el acetábulo mediante una revolución (Figura 7.3).




Figura 7. 3 Croquis y diseño 3D de la cabeza.

Para el vástago se ha hecho el diseño mediante una extrusión a la que posteriormente se le realizó en las aristas un redondeo (Figura 7.4).

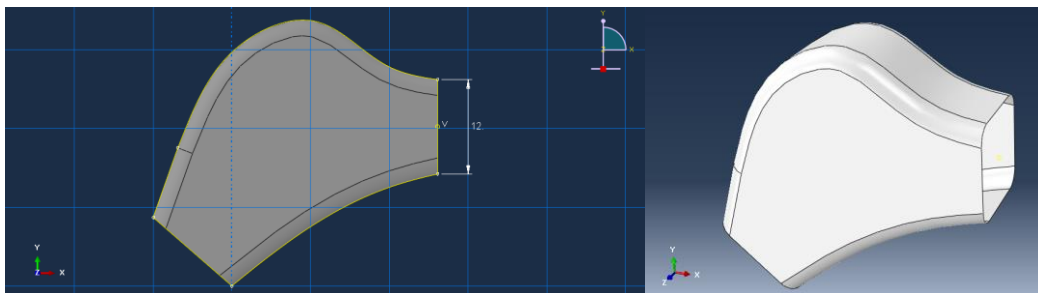


Figura 7. 4 Croquis y diseño 3D del vástago.

Quedando la prótesis una vez unidas la cabeza y el vástago de tal forma (Figura 7.5).




Figura 7. 5 Modelo 3D de la prótesis.

En cuanto al modelo de elementos finitos simulados, el acetábulo ha sido mallado con elementos hexaédricos, la cabeza y el vástago con elementos tetraédricos y cuadriláteros respectivamente con el fin de reproducir la geometría con suficiente exactitud.

A continuación, se va a mostrar una tabla en la que puede observar los elementos y nodos que componen el modelo teniendo en cuenta el diámetro de la prótesis a estudiar (Tabla 7.1).

Tabla 7. 1 Elementos y modos del modelo.

Componente Ø22	Nodos	Elementos
Acetábulo	16884	15004
Cabeza y vástago	2458	2468
Componente Ø28	Nodos	Elementos
Acetábulo	12664	10914
Cabeza y vástago	2372	2392
Componente Ø32	Nodos	Elementos
Acetábulo	11352	9856
Cabeza y vástago	2754	2740
Componente Ø36	Nodos	Elementos
Acetábulo	10074	8160
Cabeza y vástago	3364	3396
Componente Ø40	Nodos	Elementos
Acetábulo	8885	6912
Cabeza y vástago	2562	2581
Componente Ø44	Nodos	Elementos
Acetábulo	7901	5774
Cabeza y vástago	2648	2670

El tamaño del elemento (1,5 mm) que se utiliza representa un buen compromiso entre la precisión numérica y el coste computacional. Se ha realizado un análisis de sensibilidad de la malla que indica que dicho tamaño es suficiente.

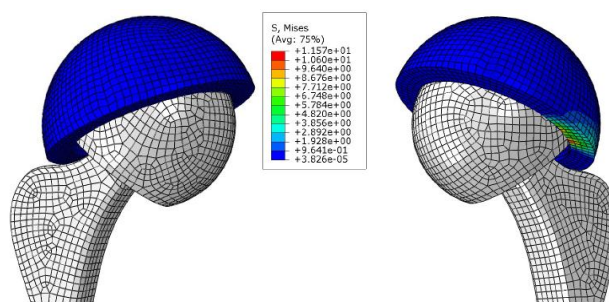


Figura 7. 6 Modelo mallado en EF.

7.1.2. Propiedades del material y no linealidad del problema simulado

Para hacer la simulación la componente acetabular se ha simulado como polietileno de peso molecular ultra alto (UHMWPE). Se le asignó un módulo elástico $E=940\text{MPa}$, un coeficiente de Poisson $\nu=0,3$ y un límite de fluencia de $26,26\text{MPa}$ (Kluess et al., 2007).


La cabeza y el vástago de la prótesis han sido simulados como una superficie rígida. El módulo elástico del titanio ($105\text{-}120\text{GPa}$, dependiendo de la aleación) como se puede observar es bastante más alta que la del polietileno y podemos despreciar su deformación con respecto a la del acetábulo.

En cuanto a las propiedades de contacto se ha asignado la cabeza y el cuello como superficies maestras y la semiesfera interna del acetábulo y la corona circular como superficie esclava. Se introdujo un comportamiento mecánico tangencial isótropo, con un coeficiente de fricción de $0,038$ (Pedersen et al., 2005).

Los análisis que se han realizado son altamente no lineales debido a los grandes desplazamientos, a la definición no lineal del material y al contacto entre componentes.

7.1.3. Condiciones de contorno y movimientos simulados

Las condiciones de contorno que se simularon, impedían la traslación en los ejes X, Y y Z de la componente acetabular y de la cabeza de la componente femoral como podemos ver los ejes en la Figura 7.6. También se ha restringido la rotación de la cabeza de la componente femoral en los ejes en los que no se le aplicó el giro. Para simular los movimientos que generan la luxación, las rotaciones se han aplicado en un punto de referencia del centro de la cabeza de la componente femoral (Figura 7.7).



*Figura 7. 7 Modelo 3D de la prótesis
con sus ejes de coordenadas.*




Figura 7. 8 Movimientos de la prótesis.

Con respecto a los ángulos de abducción (α) y anteversión (β) (Figura 7.8), se han establecido los siguientes valores, para abducción (α) se han fijado unos ángulos de 20°, 30°, 40°, 50°, 60° y 70°, los ángulos que se han usado para la anteversión (β) han sido de 0°, 5°, 10°, 20°, 30° y 40° (Figura 7.9).




Figura 7. 9 Modelo 3D combinación de ángulos (Anteversión y Abducción).

Para cada combinación de los factores que hemos citado anteriormente se han estudiado dos posiciones, flexión de 90°, que es equivalente a un paciente cuando está sentado y extensión con 0°, equivale cuando el paciente está de pie. En cada uno de los dos casos se analizó el efecto de la rotación externa e interna hasta que se producía el choque entre componentes y la luxación protésica (Figura 7.10).




Figura 7. 10 Modelo 3D de las rotaciones simuladas (a) Extensión (b) Flexión en el momento de producirse el impingement.

7.2. DESARROLLO DE LA HERRAMIENTA MEDIANTE REDES NEURONALES

La herramienta preclínica está formada por cuatro redes neuronales artificiales independientes (Figura 7.11). La primera red neuronal es (IMP-EE) que predecirá cuando se produce el impingement en el caso de la extensión-externa; la segunda red neuronal es (IMP-FI) que esta red también predice cuando se produce el impingement, pero este caso es cuando la prótesis está en flexión-interna. Para detectar la luxación de cadera se usarán dos redes más, la primera red de detección de la luxación es (LUX-EE) que predice cuando se produce la luxación en el momento que esta la prótesis en extensión-externa, la última red detectará la luxación es (LUX-FI) que en este caso te predice la luxación cuando está en flexión-interna.




Figura 7. 11 Esquema de la herramienta preclínica.

7.2.1. Entradas de la herramienta

Todos los parámetros anatómicos que se necesita de cada paciente se han de poder obtener mediante coxometría de radiología simple para ello el estudio radiográfico debe incluir dos proyecciones. Por un lado, una proyección pélvica anteroposterior de la que se obtienen los parámetros del diámetro de la cabeza protésica y el ángulo de abducción midiéndolos sobre la radiografía obtenida (Figura 7.12 (a)). Para la radiografía anteroposterior de la pelvis, (Figura 7.12 (b)), el paciente se coloca en decúbito supino con las piernas en 15° de la rotación interna, para compensar la anteversión femoral y obtener los parámetros anatómicos de esta forma en verdadera magnitud.




Figura 7. 12 (a) Coxometría de parámetros anatómicos y (b) Proyección anteroposterior.

Por otro lado, para la obtención del parámetro anatómico del ángulo de anteversión, se ha de medir el este ángulo mediante una radiografía. Para ello se ha de seguir el método descrito por (Dunlap et al., 1953). Se realiza una proyección radiológica en sentido anteroposterior con el paciente colocado en decúbito supino con las caderas en rotación neutra y rodillas flexionadas a 90°. Los muslos en abducción de 10° y piernas perpendiculares a la placa radiográfica (Figura 7.13 (a y b)). El foco del rayo debe ser perpendicular a la mesa de radiología y centrado en la sínfisis púbica. La obtención de esta proyección (Figura 7.14 (a)), nos permitirá medir en la radiografía obtenida "el ángulo aparente de torsión del cuello femoral" realizando la intersección entre el eje del cuello y el eje bicondíleo o borde inferior de la radiografía. Este ángulo así obtenido nos permitirá conocer el ángulo anteversión aparente y con dicho valor mediante la tabla de conversión de la Figura 7.14 (b) En función del ángulo de inclinación se obtiene el ángulo de anteversión verdadero.




Figura 7. 13 Proyección de Dunlap con cadera en flexión de 90° y muslo en abducción de 10°.





Figura 7. 14 Obtención del ángulo de anteversión (a) aparente y (b) verdadero.

7.2.2. Salidas de la herramienta

El objetivo que tiene cada red neuronal es que sea capaz de dar la información necesaria al médico según los parámetros de cada paciente para poder predecir el mayor ángulo que podría moverse el paciente antes de que se produzca la luxación de cadera. Para ello, el médico tendrá que introducir el tamaño de diámetro que tiene la prótesis, el ángulo de abducción y el ángulo de anteversión, para que la red proporcione el ángulo de movimiento en el que se produce la luxación. Las salidas serán cada uno de los riegos en luxación que se encuentran normalizados con rango de [0,1] respecto a sus valores máximos y mínimos de cada luxación se puede decir que los valores muy próximos a 0 indican un riesgo alto, ya que tienen un menor ángulo de movimiento, los valores en torno al 0,25 indican un riesgo medio y los valores muy próximos a 1 indican un riesgo bajo porque equivaldría a un mayor rango de movimiento y por tanto un mayor dificultad para que se produzca la luxación de cadera, como se puede ver en la Figura 7.15.

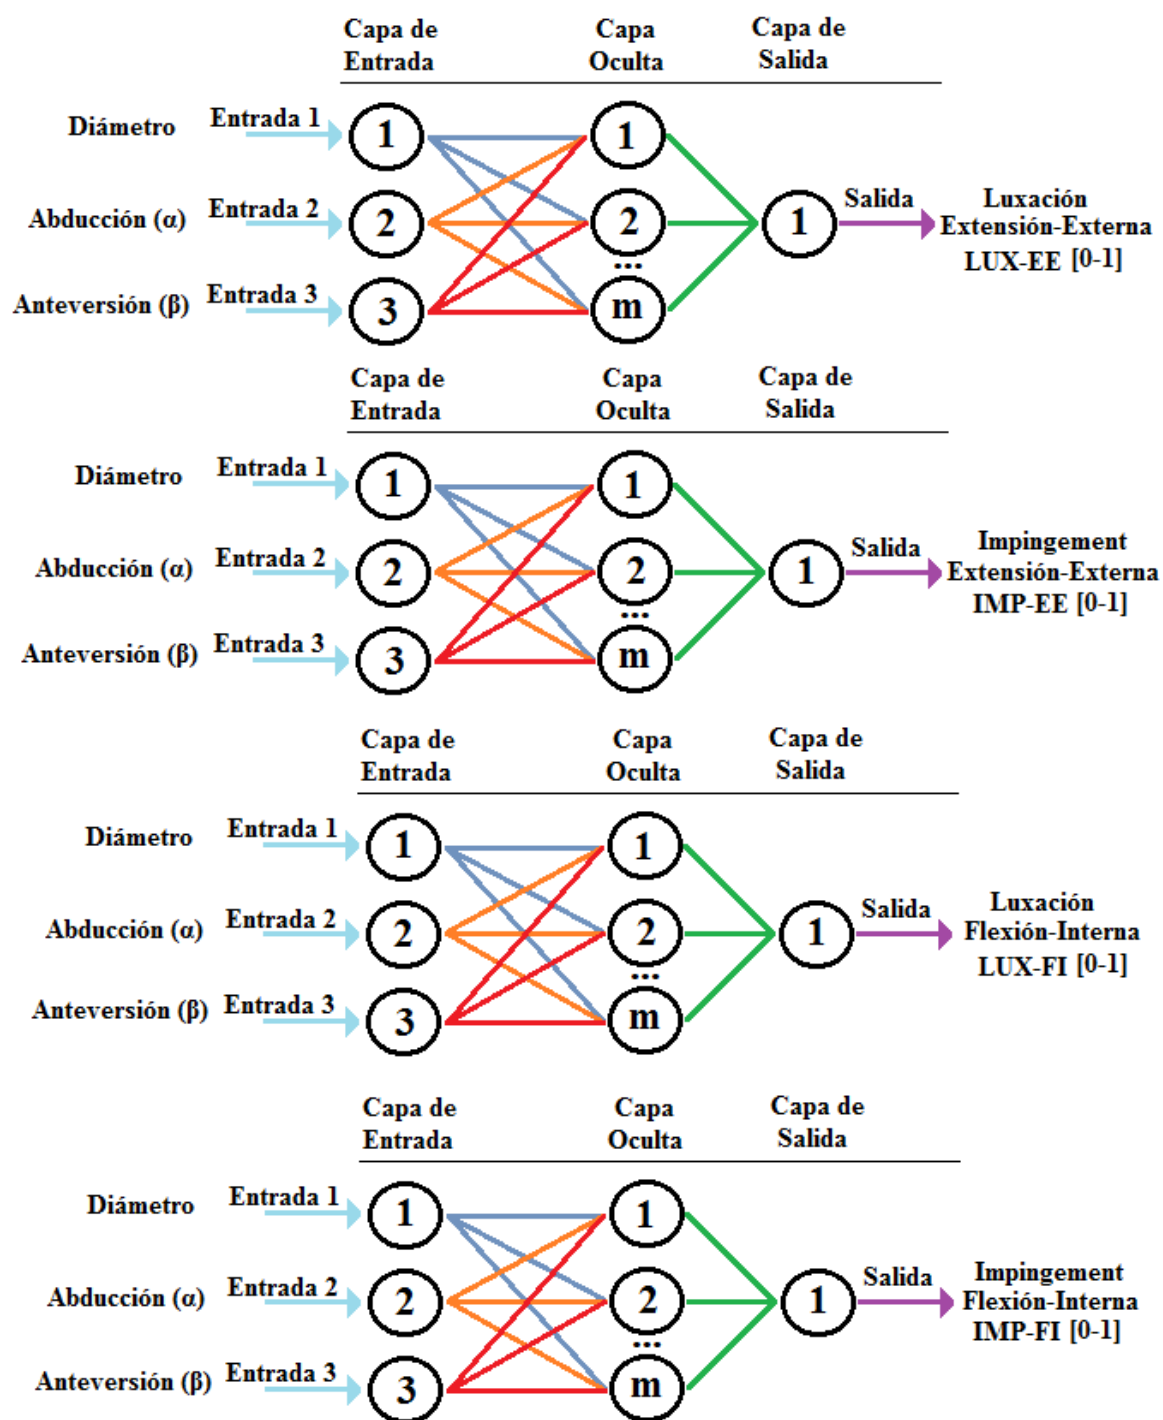


Figura 7. 15 Estructura interna Red neuronal.

7.2.3. Entrenamiento de la herramienta

Para hacer el entrenamiento de cada red neuronal se ha utilizado el algoritmo Backpropagation. Cada red neuronal artificial tendrá una única salida correspondiente al ángulo de luxación o impingement según la red que se esté trabajando.

Para la capa oculta se tiene que hacer un análisis entre diferentes neuronas intermedias, en este caso de 10 a 70 neuronas, para poder determinar con cuántas neuronas se obtiene una mejor calidad de respuesta. Todo esto se va a llevar a cabo con diferentes entrenamientos con distintos números de neuronas y se va a evaluar la calidad del resultado en función de los errores de aprendizaje y test.

El programa que se va a usar para hacer el entrenamiento de redes neuronales, en este caso se ha elegido el módulo Neural Network Training de Matlab (Figura 7.16). El programa de la red neuronal dispondrá de los siguientes parámetros de entrenamiento básico:

- Net.trainParam.show=5 (Muestra los resultados del entrenamiento cada 5 ciclos)
- Net.trainParam.epochs=5000
- Net.trainParam.goal=1e-20 (Muestra los resultados del entrenamiento con el error objetivo)

El entrenamiento se hará correctamente cuando se llegue al final de los ciclos o cuando se consiga que el error entre los datos obtenidos por la red llegue al objetivo planteado. Se van a realizar los entrenamientos con 5000 iteraciones ya que ha probado con 1000 y 10000 iteraciones y se ha podido comprobar que con 1000 iteraciones se obtiene peores resultados y con 10000 iteraciones se han obtenido resultados bastantes parecidos a los de 5000 pero con un tiempo de ejecución bastante mayor. Estos parámetros se aplicarán a estudiar el efecto del número de neuronas en la capa oculta (10, 20, 30, 40, 50, 60, y 70), eligiéndose aquel caso que dé lugar a la red con menores errores de entrenamiento y test.



Figura 7. 16 Entrenamiento de la red con Matlab.

7.2.4. Evaluación de los entrenamientos

Para poder evaluar correctamente cada entrenamiento se ha implementado en cada red neuronal artificial la técnica de validación cruzada. Esta técnica consiste en dividir los datos de la muestra en dos subconjuntos, normalmente hay tres tipos de muestras 90-10, 80-20 y 70-30, que para este trabajo se ha decidido usar la muestra de 90-10 ya que es la que mejor resultados se han obtenido. Para este caso el primer subconjunto utilizado consiste para entrenar el modelo (90% de los datos) y el otro subconjunto se utiliza para validar y testear el modelo (10% de los datos). Esta técnica es aleatoria y se han realizado 10 iteraciones y para cada una de estas iteraciones, el subconjunto de validación ha ocupado una posición diferente a lo largo de los datos de la muestra (Figura 7.17).




Figura 7. 17 Esquema de validación cruzada.

La ventaja que tiene la validación cruzada es que utiliza todos los datos disponibles de entrenamiento y el error final es independiente de los datos seleccionados en cada entrenamiento. Con el fin de predecir una mayor exactitud de cada caso en la red neuronal artificial se ha utilizado el error relativo en cuya ecuación intervienen los datos de la predicción $\hat{\theta}$, y los datos reales θ .

$$\text{Error relativo} = \text{abs} \frac{\hat{\theta} - \theta}{\theta} \quad (7.1)$$

Los resultados obtenidos en el error relativo se obtienen calculando en base a los subconjuntos de test y aprendizaje de la validación cruzada. Estos datos se utilizan para generar el modelo, de manera que el correspondiente error nos indicará si el modelo se ha entrenado correctamente. Por otro lado, los datos de test se utilizan para validar el modelo, de manera que el correspondiente error nos indica si el modelo es adecuado para simular y predecir la luxación.

- **Error de aprendizaje:** Corresponde a los errores obtenidos en función de los datos con que se ha entrenado el modelo, que son los mismos que los que se han utilizado para enseñar la red neuronal.
- **Error de test:** Compara el error que se produce al introducir en la red datos que no se han utilizado anteriormente, comparándolo posteriormente con los obtenidos en los casos simulados.

8. RESULTADOS

8.1. RESULTADOS DEL MODELO POR ELEMENTOS FINITOS

8.1.1. Posición del acetábulo y diámetro de la cabeza protésica

Respecto a la posición del acetábulo, a continuación, se va a ver como varían los diferentes parámetros con los distintos ángulos en función del tamaño de la cabeza, en el caso del paciente en extensión y en flexión como se puede ver en la Figura 8.1 un ejemplo de cómo afectaría en el impingement y la luxación.




Figura 8. 1 Estudio de Abaqus del Impingement y la Luxación.

En primer lugar y fijando para cada caso un diámetro de cabeza diferente, del mismo modo variando los parámetros de abducción y anteversión se obtiene un rango de movimiento en grados en el momento del choque (impingement) y de luxación diferente en cada caso. Como se puede observar en las siguientes imágenes (Figura 8.1-8.6) cuanto mayor es el diámetro de la cabeza mayor es el ángulo para que se produzca una luxación con un ángulo menor de abducción (α), por tanto, es mejor el resultado que se obtiene, se pueden observar los mismos resultados en las tablas de forma numérica mostrados en el Anexo1 (Tabla A1.1-A1.6). Aumentar el ángulo de movimiento, implica que la luxación es más difícil que se produzca.

Resultados




Figura 8. 2 Resultados Diámetro 22mm.




Figura 8. 3 Resultados Diámetro 28mm.




Figura 8. 4 Resultados Diámetro 32mm.




Figura 8. 5 Resultados Diámetro 36mm.

Resultados




Figura 8. 6 Resultados Diámetro 40mm.




Figura 8. 7 Resultados Diámetro 44mm.

8.2. VALIDACIÓN DE LA HERRAMIENTA PRECLÍNICA DE PREDICCIÓN DE LUXACIÓN DE CADERA

En la Figura 8.8 se muestran los errores de aprendizaje y test para las cuatro redes neuronales. Se ha analizado el efecto tanto del número de iteraciones en el entrenamiento como el número de neuronas de la capa oculta y el número de datos con los que va a trabajar la red. Respecto al número de iteraciones se ha optado por 5000 iteraciones ya que son la que mejor resultado porque si aumentamos el número de iteraciones, los errores se reducirán un poco, pero el coste computacional del entrenamiento subirá exponencialmente. Como se puede ver en las gráficas de la Figura 8.7 se observa que se produce en algún caso sobre aprendizaje. Con respecto a la elección del número de neuronas para cada red se han tenido en cuenta lo siguiente:

- Error training < Error test
- RSQ \approx 0,99 (mejor caso)
- RSQ > 0,80

Por ello, en la primera red (IMP-EE) con todos los datos estudiados se ha elegido usar 30 neuronas, en la segunda red (IMP-FI) también se usarán 30 neuronas, para la tercera red (LUX-EE) la mejor opción son 50 neuronas y para la última red (LUX-FI) si fijaran 20 neuronas en la capa oculta como podemos ver en la Figura 8.8.

Resultados

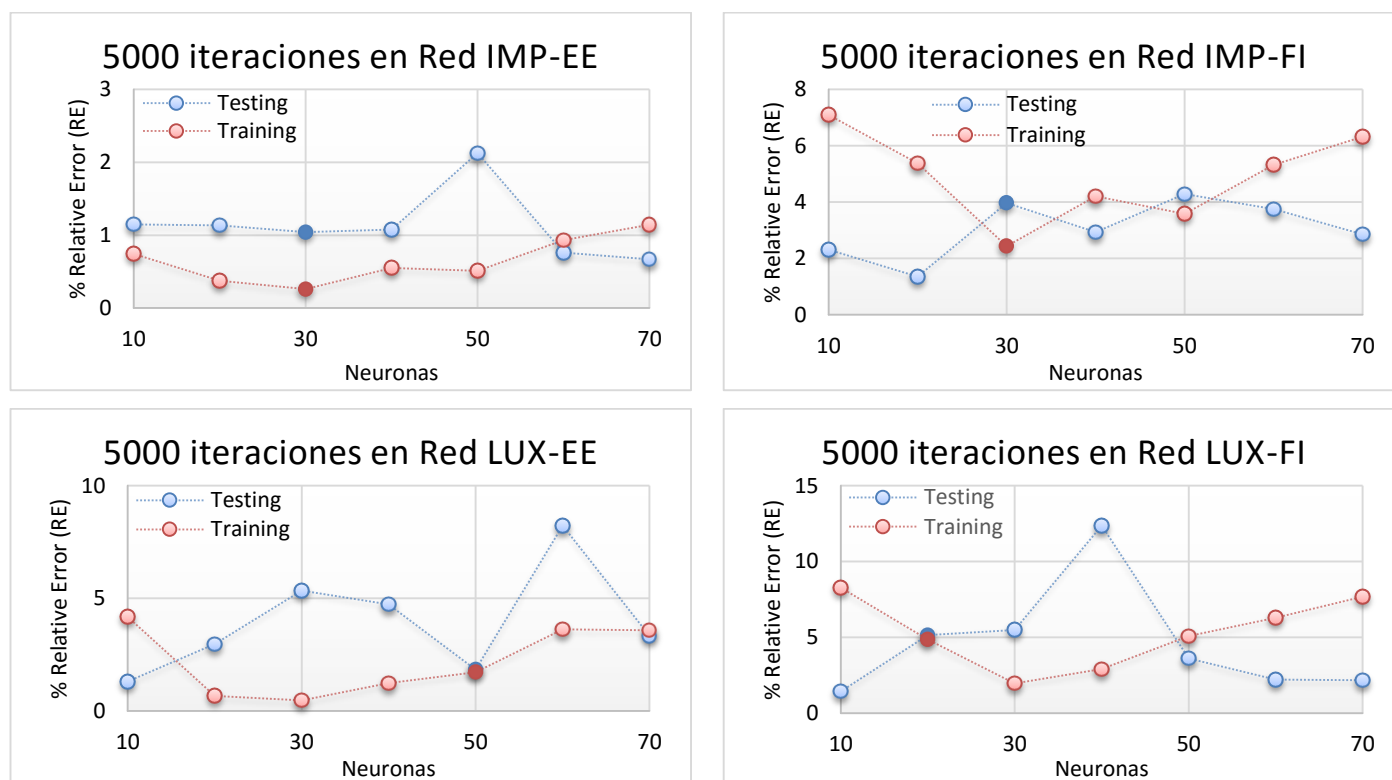


Figura 8. 8 Elección de la red más adecuada.

Una vez que se ha hecho la herramienta preclínica hay que hacer una validación para comprobar si es una herramienta que podrían usar los médicos sin ningún problema obteniendo unos buenos resultados a la hora de predecir los casos de los pacientes. Para ello, se han utilizado unos casos diferentes de los del entrenamiento de la red. Los casos que se han introducido en la herramienta son unos casos totalmente diferentes ya que se han utilizado el diámetro de casos anteriores, pero se han modificado los ángulos de abducción y anteversión. Estas validaciones igual que en el entrenamiento de redes se han realizado para las cuatro redes (IMP-EE, IMP-FI, LUX-EE y LUX-FI).

Se determina mediante la realización de un análisis de regresión lineal comprobando su valor estadístico, R^2 , denominado coeficiente de determinación. Obteniendo unos valores de $R^2=0,8283$ y $R^2=0,8182$ para el caso del impingement (extensión externa y flexión interna, respectivamente) cuyas ecuaciones de las líneas de regresión lineal son mostradas en la Figura 8.9.




Figura 8. 9 Comparativas de resultados del método de EF con el método de Redes Neuronales: a) red IMP-EE y b) red IMP-FI.

De igual modo se han obtenido los valores de $R^2=0,8459$ y $R^2=0,95$ para los casos de luxación (extensión externa y flexión interna, respectivamente) y ecuaciones de las líneas de regresión lineal son mostradas en la Figura 8.10.




Figura 8. 10 Comparativas de resultados del método de EF con el método de Redes Neuronales: a) red LUX-EE y b) red LUX-FI.

8.3. RESULTADOS DE LA HERRAMIENTA PRECLÍNICA

Una vez realizada la validación de las cuatro redes neuronales estas pueden ser utilizadas para el fin con el que fueron diseñadas, concluir o predecir el riesgo de fractura de pacientes específicos para distintas situaciones de luxación de cadera.

Se define un criterio de clasificación según riesgo bajo, medio o alto (Figura 8.11) ya que es el objetivo final del estudio y lo que tanto el paciente como el médico quieren llegar a conocer. Se clasifica como **riesgo alto de luxación** cuando el valor se encuentra por debajo del 0,05 que equivale entre 0° y 10° de movimiento, el **riesgo medio de luxación** se encuentra entre los valores 0,05 y 0,25 que en grados equivaldría entre 10° y 45°, por último, el **riesgo bajo de luxación** se encuentra entre los valores 0,25 y 1 que sería entre 45° y 180°.

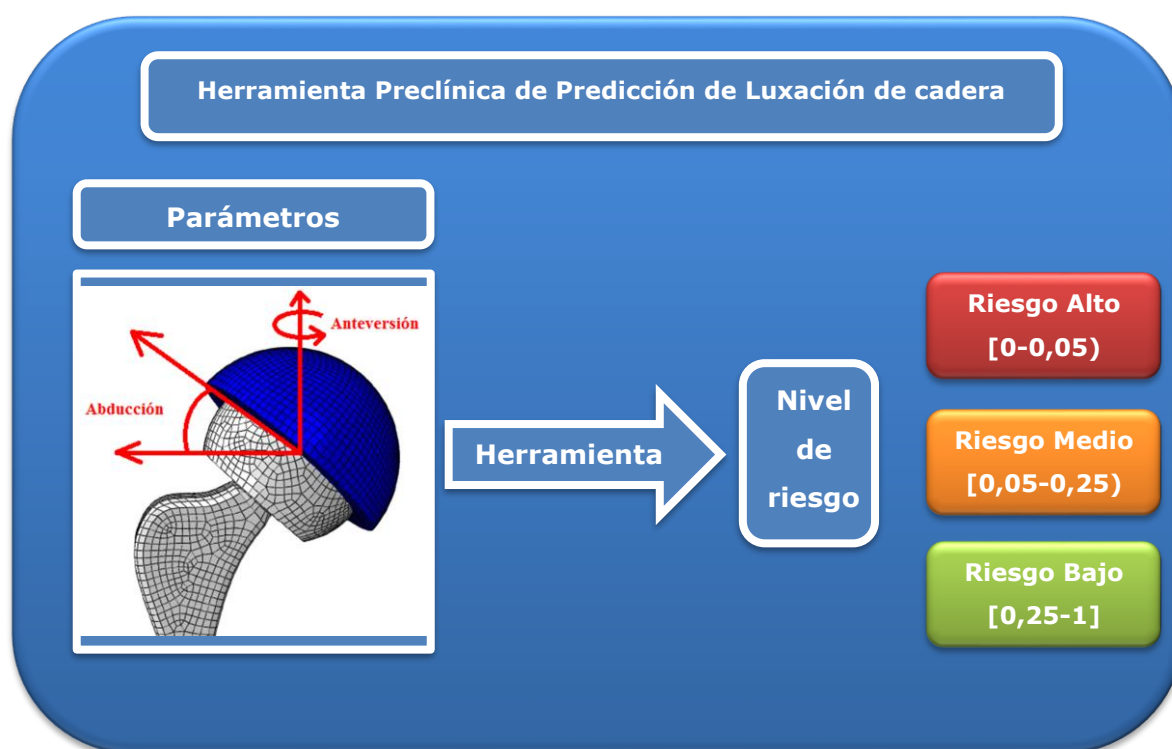


Figura 8. 11 Rango de resultados de la Herramienta Preclínica.

En esta herramienta se introducen los parámetros de la prótesis de cada paciente identificados como (ID1 a ID20) en las redes IMP-EE, IMP-FI, LUX-EE y LUX-FI obteniéndose los resultados del riesgo de cada tipo de fractura en la Tabla 8.1.

Tabla 8. 1 Resultados de la herramienta preclínica.

PARÁMETROS ANATÓMICOS DEL PACIENTE				RIESGO DE LUXACIÓN DE CADERA			
Paciente	Diámetro	Alfa Abducción	Beta Anteversión	IMP-EE	IMP-FI	LUX-EE	LUX-FI
ID1	28	25	0	0,6749	0,0645	0,8362	0,0221
ID2	28	35	0	0,5588	0,0547	0,6480	0,0783
ID3	28	45	0	0,5172	0,0334	0,5535	0,1348
ID4	28	25	15	0,4303	0,0564	0,5563	0,1125
ID5	28	40	15	0,4029	0,1108	0,4463	0,2117
ID6	28	60	15	0,3786	0,4879	0,4307	0,3455
ID7	28	60	25	0,3551	0,3994	0,3494	0,3843
ID8	28	40	25	0,2793	0,1627	0,3351	0,2437
ID9	28	25	25	0,3121	0,0676	0,3721	0,1507
ID10	32	25	15	0,4761	0,0551	0,5803	0,1161
ID11	32	40	15	0,4240	0,1174	0,4674	0,2065
ID12	32	60	15	0,3652	0,2818	0,4396	0,3441
ID13	32	25	25	0,3250	0,1206	0,3971	0,1490
ID14	32	40	25	0,3187	0,1818	0,3580	0,2352
ID15	32	60	25	0,3141	0,2582	0,3618	0,3743
ID16	36	60	25	0,3081	0,2794	0,3642	0,3545
ID17	36	40	15	0,4517	0,2116	0,4770	0,1884
ID18	36	60	15	0,3835	0,1621	0,4411	0,3247
ID19	36	25	25	0,3765	0,1192	0,4071	0,1391
ID20	36	40	25	0,3609	0,2001	0,3674	0,2200

Los resultados de la Tabla 8.1 muestra para cada paciente el riesgo que tienen para que se produzca una luxación de cadera. Como se puede observar hay más riesgo de luxación cuando el paciente está en flexión (Figura 8.12 (a)), es decir, cuando el paciente está sentado con las piernas cruzadas. En cambio, ningún paciente tiene problema de que se produzca una luxación cuando está en extensión (Figura 8.12 (b)).




Figura 8. 12 (a) Paciente en flexión y (b) Paciente en extensión («Guía para el paciente con Prótesis Total de Cadera», s. f.).

9. CONCLUSIONES Y LÍNEAS FUTURAS

9.1. CONCLUSIONES

A continuación, se van a mostrar las conclusiones más destacables del trabajo realizado de investigación en este Trabajo Fin de Grado (TFG):

En primer lugar, respecto al modelo paramétrico en Elementos Finitos (EF) desarrollado, se puede obtener varias conclusiones fundamentales. La primera conclusión es que se puede afirmar que dependiendo de los distintos parámetros que se utilicen en la colocación del acetábulo el ángulo de movimiento para que se produzca una luxación de cadera puede variar bastante. Del mismo modo se han deducido unos intervalos de los parámetros en los que debería estar colocado la prótesis de cadera para que tenga un mayor ángulo de movimiento y le cueste más que se produzca la luxación, por tanto, la prótesis tendría que estar situada en un ángulo de **abducción** entre **40° y 60°** y un ángulo de **anteversión** entre **10° y 30°** (Figura 9.1).




Figura 9. 1 Zona de seguridad.

También se ha descubierto que con el aumento del tamaño de la cabeza de la prótesis se produce un menor desgaste del acetábulo, por tanto, puede aguantar más tiempo para que se produzca la luxación y por tanto, mayor zona de seguridad.

Con respecto a la herramienta preclínica, se pueden obtener varias conclusiones fundamentales. La primera de ellas es que ha querido hacer que el estudio tenga una finalidad práctica, por ello, se han convertido los resultados mecánicos en resultados preclínicos. De tal manera que esta herramienta pueda ser utilizada por el personal médico y pueda observar el riesgo que habría para que se produzca una luxación de cadera en un paciente de manera automática introduciendo los parámetros concretos del paciente en la herramienta predictiva (Figura 9.2).



Figura 9. 2 Proceso del estudio de la luxación de cadera específico para un paciente.

Como se ha podido observar anteriormente el médico tendría un porcentaje de acierto diferente para cada tipo de estudio que quiera realizar, en el caso del **Impingement en Extensión Externa** sería un acierto del **82%** para el **Impingement en Flexión Interna** un **81%** en el caso de la luxación habría un mayor acierto, ya que se produce en la **Luxación en Extensión Externa** un **84%** y en la **Luxación en Flexión Interna** un **95%** de acierto.

En relación a la herramienta preclínica se ha podido observar que los pacientes estudiados tienen más riesgo en padecer una luxación en flexión interna que en extensión externa (Figura 9.3). También puede afirmar lo estudiado anteriormente que aproximadamente un 10% de los casos puede padecer una luxación de cadera después de la operación ya que en el estudio que se ha hecho con 20 pacientes se ha podido confirmar que 2 de los pacientes podrían tener un riesgo alto de que padezca una luxación de cadera (Figura 9.4), por tanto, esos pacientes tendrían que tener unos cuidados preventivos correspondientes para que no se produzca la luxación.




Figura 9. 3 Porcentaje de riesgo a) Impingement Extensión-Externa; b) Impingement Flexión-Interna; c) Luxación Extensión-Externa y d) Luxación Flexión-Interna.




Figura 9. 4 Porcentaje de riesgo de luxación de cadera por paciente.

9.2. FUTURAS LÍNEAS DE INVESTIGACIÓN

En cuanto a posibles mejoras a realizar en este proyecto para futuras investigaciones podrían ser:

- Mejorar el modelo de elementos finitos incorporándoles tejidos blandos de la articulación. Esto ayudaría a que se retrase la luxación. Así poder hacer el estudio con diferentes parámetros de los que se han estudiado para añadirlos a los ya existentes y así poder mejorar los resultados obtenidos en las redes neuronales, de este modo el médico podrá predecir con mayor exactitud los resultados de cada paciente.
- En relación del trabajo computacional, desarrollar un único software más sencillo para que el personal médico del hospital pueda predecir con una mayor rapidez el rango de movimiento en el que se produzca la luxación de cadera de cada paciente introduciendo sus parámetros geométricos y clínicos que necesiten.

10. BIBLIOGRAFÍA

1. Ameneiro-Romero, L., Souto-Rey, V., Miranda-Blanco, J. M., & Baña-Sandá, F. (2005). Factores de riesgo y tratamiento de las luxaciones de prótesis de cadera: nuestra experiencia. *Acta Ortop. Gallega*, 1(2), 66–70.
2. Annabell, la red de neuronas artificiales. (2016, febrero 4). Recuperado 15 de febrero de 2016, a partir de http://www.cienciaplor.com/innovacion/annabell-red-neuronas-artificiales-que-aprendido-hablar-como-nino_2015121800177.html
3. BIOLOGIA SISTEMA APARATO: IMAGENES DEL HUESO FEMUR. (2011, abril 1). Recuperado a partir de <http://biologiafotosdibujosimagenes.blogspot.com.es/2011/04/imagenes-del-hueso-femur.html>
4. Biomecánica. (2016, enero 31). En *Wikipedia, la enciclopedia libre*. Recuperado a partir de <https://es.wikipedia.org/w/index.php?title=Biomec%C3%A1nica&oldid=88832096>
5. Blom, A. W., Rogers, M., Taylor, A. H., Pattison, G., Whitehouse, S., & Bannister, G. C. (2008). Dislocation Following Total Hip Replacement: The Avon Orthopaedic Centre Experience. *The Annals of The Royal College of Surgeons of England*, 90(8), 658-662. <http://doi.org/10.1308/003588408X318156>
6. Casos clinicos de residentes SECOT - Visor. (s. f.). Recuperado 11 de marzo de 2016, a partir de <https://www.secot.es/visor/caso.php?id=225&Anual=2010>
7. Chinrungrueng, C. (1988). *Analysis of Simple Neural Networks*.

8. CIENCIAS BIOLOGICAS: ANATOMIA Y FISIOLOGIA DEL SISTEMA OSEO. (s. f.). Recuperado a partir de <http://hnnbiol.blogspot.com.es/2008/01/sistema-oseo.html>
9. Daly, P. J., & Morrey, B. F. (1992). Operative correction of an unstable total hip arthroplasty. *The Journal of Bone and Joint Surgery. American Volume*, 74(9), 1334-1343.
10. Dunlap, K., Shands, A. R., Hollister, L. C., Gaul, J. S., & Streit, H. A. (1953). A new method for determination of torsion of the femur. *The Journal of Bone and Joint Surgery. American Volume*, 35-A(2), 289-311.
11. Fritsch, J. (1996). *Modular Neural Networks for Speech Recognition*. DTIC Document. Recuperado a partir de <http://oai.dtic.mil/oai/oai?verb=getRecord&metadataPrefix=html&identifier=ADA326090>
12. Guía básica tras PTC por vía posterior (en construcción). (2012, febrero 11). Recuperado a partir de <https://traumatologiahellin.wordpress.com/recomendaciones/guia-basica-tras-ptc-por-via-posterior-en-construccion/>
13. Guía para el paciente con Prótesis Total de Cadera. (s. f.). Recuperado a partir de <http://doctoravaldazo.com/guia-para-el-paciente-con-protesis-total-de-cadera/>
14. Gurney, K. (1997). *An Introduction to Neural Networks*. CRC Press.
15. INTELIGENCIA ARTIFICIAL. (s. f.). Recuperado 20 de febrero de 2016, a partir de http://elportaldebucanero.mex.tl/1800617_inteligencia-artificial.html
16. Isasi Viñuela, P., & Galván León, I. M. (2004). Redes de neuronas artificiales: un enfoque práctico.

Bibliografía

17. Kluess, D., Martin, H., Mittelmeier, W., Schmitz, K.-P., & Bader, R. (2007). Influence of femoral head size on impingement, dislocation and stress distribution in total hip replacement. *Medical Engineering and Physics*, 29(4), 465-471. <http://doi.org/10.1016/j.medengphy.2006.07.001>
18. Martín Gracia. (2009, julio). *Luxaciones*. Universidad Nacional de Colombia. Recuperado a partir de http://es.slideshare.net/martin_gia_s/luxaciones-7409002
19. Martínez, J., López, M., Matías, J. M., & Taboada, J. (2013). Classifying slate tile quality using automated learning techniques. *Mathematical and Computer Modelling*, 57(7-8), 1716-1721. <http://doi.org/10.1016/j.mcm.2011.11.016>
20. Masaoka, T., Yamamoto, K., Shishido, T., Katori, Y., Mizoue, T., Shirasu, H., & Nunoda, D. (2006). Study of hip joint dislocation after total hip arthroplasty. *International Orthopaedics*, 30(1), 26-30. <http://doi.org/10.1007/s00264-005-0032-4>
21. Meek, R. M. ., Allan, D. B., McPhillips, G., Kerr, L., & Howie, C. R. (2008). Late Dislocation after Total Hip Arthroplasty. *Clinical Medicine & Research*, 6(1), 17-23. <http://doi.org/10.3121/cmr.2008.770>
22. Moore, K. L., & Dalley, A. F. (2009). *Anatomía con orientación clínica*. Ed. Médica Panamericana.
23. Músculo pectíneo. (2015, diciembre 25). En *Wikipedia, la enciclopedia libre*. Recuperado a partir de https://es.wikipedia.org/w/index.php?title=M%C3%BAsculo_pect%C3%ADneo&oldid=88005951
24. Nascimento, C. A. O., Giudici, R., & Guardani, R. (2000). Neural network based approach for optimization of industrial chemical processes. *Computers &*

- Chemical Engineering*, 24(9–10), 2303-2314. [http://doi.org/10.1016/S0098-1354\(00\)00587-1](http://doi.org/10.1016/S0098-1354(00)00587-1)
25. Padgett, D. E., & Warashina, H. (2004). The unstable total hip replacement. *Clinical Orthopaedics and Related Research*, (420), 72-79.
26. Pedersen, D. R., Callaghan, J. J., & Brown, T. D. (2005). Activity-dependence of the «safe zone» for impingement versus dislocation avoidance. *Medical Engineering and Physics*, 27(4), 323-328.
<http://doi.org/10.1016/j.medengphy.2004.09.004>
27. Popowski, G., Gebhart, M., Benkirane, A., Petein, M., & Van Houtte, P. (1991). [Osteoradionecrosis at the level of coxo-femoral articulation in the adult]. *Acta Chirurgica Belgica*, 91(5), 258-264.
28. Pritzker, K. P. H. (2009). Counterpoint: Hydroxyapatite crystal deposition is not intimately involved in the pathogenesis and progression of human osteoarthritis. *Current Rheumatology Reports*, 11(2), 148-153.
29. Prótesis acetabular clásica / no cementada - Plasmacup® Acetabular Cup. (s. f.). Recuperado 27 de febrero de 2016, a partir de <http://www.medicalexpo.es/prod/aesculap-b-braun-company/product-70641-663430.html>
30. Recomendaciones para pacientes con prótesis total de cadera | Blog de San Vicente Fundación. (s. f.). Recuperado a partir de http://www.elhospitalblog.com/vida_sana/cuidados-del-paciente/recomendaciones-para-pacientes-con-protesis-total-de-cadera/
31. Redes Neuronales. (s. f.). Recuperado 15 de febrero de 2016, a partir de https://www.ibiblio.org/pub/linux/docs/LuCaS/Presentaciones/200304curso-glisa/redes_neuronales/curso-glisa-redes_neuronales-html/x24.html

Bibliografía

32. Salud, C. Y. (2015, mayo 18). PSICOLOGIA Y CIENCIA: QUE ES LA NEURONA, TIPOS Y FUNCION. Recuperado a partir de <http://psicodesaroollo.blogspot.com.es/2015/05/que-es-la-neurona-tipos-y-funcion.html>
33. Saluspot. (s. f.). La artritis reumatoide de cadera. Recuperado 27 de febrero de 2016, a partir de https://www.saluspot.com/p/45879/?utm_source=facebook.com&utm_medium=referral&utm_campaign=Facebook%20questions%20sharing
34. SAS, I. (s. f.). Anatomía del miembro inferior. Recuperado 22 de febrero de 2016, a partir de <https://www.imaios.com/es/e-Anatomy/Miembros/Extremidad-inferior-diagramas>
35. Tortora, G. J., Derrickson, B., & Dvorkin, M. (2006). *Principios de anatomía y fisiología*. México: Médica Panamericana.
36. Trujillano Cabello, J., Badía Castelló, M., March Llanes, J., Rodríguez Pozo, á., Serviá Goixart, L., & Sorribas Tello, A. (2005). Redes neuronales artificiales en Medicina Intensiva. Ejemplo de aplicación con las variables del MPM II. *Medicina Intensiva*, 29(1), 13-20. [http://doi.org/10.1016/S0210-5691\(05\)74198-X](http://doi.org/10.1016/S0210-5691(05)74198-X)
37. von Knoch, M., Berry, D. J., Harmsen, W. S., & Morrey, B. F. (2002). Late dislocation after total hip arthroplasty. *The Journal of Bone and Joint Surgery. American Volume*, 84-A(11), 1949-1953.
38. Xin Yao. (1999). Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9), 1423-1447. <http://doi.org/10.1109/5.784219>
39. Yao, X. (1995). Evolutionary artificial neural networks. *Encyclopedia of computer science and technology*, 33, 137-170.

Relación de documentos

(X) Memoria	58	páginas
(_) Anexos	23	páginas

La Almunia, a 28 de junio de 2016

Firmado: Juan José Martínez Zapata





Universidad
Zaragoza

**ESCUELA UNIVERSITARIA POLITÉCNICA
DE LA ALMUNIA DE DOÑA GODINA (ZARAGOZA)**

Predicción de la luxación de la cadera
mediante una herramienta computacional
basada en redes neuronales

Prediction of hip dislocation by a
computational tool based on neural
networks

424.16.101

Autor:	Juan José Martínez Zapata
Director:	Mónica Remacha Andrés
Fecha:	Julio 2016

